文章编号：2095-4980(2026)01-0089-09

基于一维深度可分离卷积的轻量化辐射源识别

孙文鑫[1a]，孟　华[1b]，杨佳煌[1b]，周礼亮[*2,3]

(1.西南交通大学 a.信息科学与技术学院；b.数学学院，四川 成都 610000；2.中国电子科技集团公司 第十研究所，四川 成都 610036；3.复杂航空系统仿真全国重点实验室，四川 成都 610036)

摘　要：针对深度神经网络的辐射源个体识别技术，为达到良好的识别性能，网络深度不断增加，致使模型参数量与计算复杂度爆炸式增长，难以在边缘端算力受限的设备上部署。为此，本文提出基于一维深度可分离卷积和一维卷积块注意力模块的网络(ODCNet)架构，通过结合逐深度卷积和逐点卷积，一维深度可分离卷积有效减少了模型的参数量和计算复杂度；轻量级的一维卷积块注意力模块可有效提升模型性能，保障模型的识别能力。实验表明，ODCNet的识别性能与MobileNet V3相当，而参数量仅为MobileNet V3的11.27%，计算复杂度为MobileNet V3的17.49%，推理时间缩短至MobileNet V3的50%。

关键词：辐射源识别；模型轻量化；深度可分离卷积；卷积块注意力模块

中图分类号：TN911.72　　**文献标志码：**A　　**DOI：**10.11805/TKYDA2024568

Lightweight radiation source identification based on one-dimensional depthwise separable convolution

SUN Wenxin[1a]，MENG Hua[1b]，YANG Jiahuang[1b]，ZHOU Liliang[*2,3]

(1a.School of Information Science and Technology；1b.School of Mathematics，Southwest Jiaotong University，Chengdu Sichuan 610000，China；2.The 10th Research Institute of China Electronics Technology Group Corporation，Chengdu Sichuan 610036，China；3.National Key Laboratory of Complex Aviation System Simulation，Chengdu Sichuan 610036，China)

Abstract: For individual radiation source identification technology using deep neural networks, network depth is continuously increased to achieve good recognition performance, resulting in an explosion of model parameters and computational complexity, which makes deployment difficult on resource-constrained edge devices. To address this, this paper proposes a network architecture called ODCNet(One-Dimensional Depthwise Separable Convolution Network) based on one-dimensional depthwise separable convolution and one-dimensional convolutional block attention modules. By combining depthwise and pointwise convolutions, one-dimensional depthwise separable convolution effectively reduces model parameters and computational complexity. The lightweight one-dimensional convolutional block attention module can effectively enhance model performance and ensure recognition capability. Experimental results show that ODCNet's recognition performance is comparable to MobileNet V3, while its parameters are only 11.27% of MobileNet V3's, its computational complexity is 17.49% of MobileNet V3's, and its inference time is reduced to 50% of MobileNet V3's.

Keywords: radiation source identification; model lightweight; depthwise separable convolution; convolutional block attention module

收稿日期：2024-10-22；**修回日期：**2024-11-18

***通信作者：**周礼亮　email:levin_1221@163.com

引用格式：孙文鑫,孟华,杨佳煌,等. 基于一维深度可分离卷积的轻量化辐射源识别[J]. 太赫兹科学与电子信息学报, 2026,24(1):89-97. DOI:10.11805/TKYDA2024568.

Citation format: SUN Wenxin,MENG Hua,YANG Jiahuang,et al. Lightweight radiation source identification based on one-dimensional depthwise separable convolution[J]. Journal of Terahertz Science and Electronic Information Technology, 2025,24(1):89-97. DOI:10.11805/TKYDA2024568.

辐射源识别是通过设备指纹信息识别具体辐射源的技术。辐射源识别技术在军事和民用领域中具有极其重要的应用价值，它可以快速准确地识别出对方的电磁辐射源，验证对方身份从而采取有效的应对措施[1]。辐射源识别技术分为传统识别方法和基于深度学习的识别方法两大类。

传统的辐射源识别方法依赖于人工提取信号特征，常用的信号特征包括幅度相位特征、时频特征[2-3]和高阶统计量特征等。S D'Agostino[4]提出脉冲振幅无意调制(Amplitude Unintentional Modulation On Pulse，A-UMOP)特征提取算法，绘制辐射源在特征空间中的分布，分析信号幅度特征在辐射源识别中的作用。J Toonstra 等[5]使用小波分析来表征射频指纹特征(Radio Frequency Fingerprinting，RFF)，进而使用反向传播网络进行分类识别。Y SHI 等[6]基于信息论研究雷达信号在调制域的辐射特征，然后使用决策树识别多输入多输出(Multiple-Input Multiple-Output，MIMO)设备。YUAN 等[7]提出基于时间-频率-能量分布(Time-Frequency-Energy Distribution，TFED)方法提取区分度较高的 13 个特征形成设备指纹信息，进而使用主成分分析法降维、支持向量机分类。传统的辐射源识别方法受限于先验知识，并且普适性较低，难以适应电磁环境复杂的情况。

近年来，基于深度学习的辐射源识别技术以其对先验知识要求较低、提取特征更加充分等优势而迅速发展。深度学习利用深度神经网络自动学习和提取辐射源的指纹特征，大大提高了识别精确度，更适用于电磁环境复杂、特征提取难度较大的情况[8]。XIAO 等[9]基于一维卷积的卷积神经网络提取信号的精细特征。WU 等[10]提出带有注意力机制的一维卷积神经网络-注意力机制模型(1D Convolutional Neural Network with Attention Mechanism，CNN-1D-AM)，在取得了良好的识别效果同时增强了模型的实时性能。ZHU 等[11]使用复卷积神经网络充分提取 I/Q 两路数据的单独特征与混合特征，相较于标准卷积网络，模型性能有所提升。LI 等[12]充分利用信号的时序特性，提出一种基于注意力机制的多循环神经网络(Recurrent Neural Network，RNN)模型，辐射源识别精确度得到进一步提升。QU 等[13]提出一维复卷积残差网络，并加入卷积块注意力模块使模型特征提取更加充分，实现了辐射源识别精确度的又一突破。

为在辐射源识别任务中取得较好的分类效果，研究者不断增加网络层数，导致深度学习模型参数量与计算复杂度急剧上升，不仅增加了模型训练时间，还不利于在计算资源有限的边缘进行部署。为解决模型深度增加引起的模型参数量与计算复杂度急剧上升这一问题，研究者开展了关于轻量化模型的研究。主流的模型轻量化技术包括量化、剪枝、知识蒸馏和轻量级网络架构设计等。其中量化、剪枝、知识蒸馏等轻量化技术性能依赖于已有的大模型，存在性能上界，而轻量级网络架构设计则可以有效避免该问题。近年来，研究者们不断探索轻量级网络架构设计。A G Howard 等[14]在 2017 年提出了基于深度可分离卷积的 MobileNets，并在细粒度识别、大规模地理定位、人脸属性、目标检测等任务中取得良好效果。ZHANG 等[15]在 2018 年提出 ShuffleNet，采用了 2 个新操作：分组点卷积和通道洗牌，在保持准确性的同时大大降低了计算成本。在 ImageNet 分类任务上，ShuffleNet 的 top-1 误差(绝对值为 7.8%)低于 MobileNet。HAN 等[16]在 2020 年采用即插即用的 Ghost 模块构建 GhostNet 模型，利用成本较低的线性变化生成包含固有特征的 ghost 特征图，并在 ImageNet ILSVRC-2012 分类数据集上，相似的计算成本获得比 MobileNetV3 更高的识别性能。

上述研究是基于图像识别任务提出的，由于图像像素点较多，模型也往往具有参数量过大，计算复杂度较高等问题，在边缘端算力受限的极限情况下，难以满足实时性这一重要指标。部分学者基于信号的时序特性开展辐射源识别任务中的轻量化模型研究。DENG 等[17]设计基于 Transformer 的轻量级网络 GLFormer，在模型中设计门控局部注意单元(Gated Local Attention Unit，GLAU)和门控滑动局部注意单元(Gated Sliding Local Attention Unit，GSLAU)模块提取射频指纹特征，大大减少了模型参数量与运算复杂度。但 Transformer 本身计算复杂度较高，经过轻量化后较卷积网络仍具有较高的计算复杂度，且 Transformer 对输入数据的敏感性较高，即噪声鲁棒性较差。基于时序性构建的模型往往在识别性能上占据优势，但对噪声敏感且复杂度较高，因此目前的轻量化辐射源识别仍以卷积神经网络为主流。随着技术的发展，学者们对卷积网络的结构进行多方面的优化，以提升辐射源个体识别的性能。王艺卉等[18]基于 Ghost 卷积提出一种适用于辐射源识别任务的轻量化模型 Ghost bottleneck，在广播式自动相关监视(Automatic Dependent Surveillance-Broadcast，ADS-B)数据集上取得了良好的轻量化效果，但识别精确度与模型鲁棒性仍有待提高。GAO 等[19]以信号的功率谱和双谱作为输入，基于深度可分离卷积的思想，并引入注意力机制重新设计了轻量级二值通道网络(Lightweight Binary Channels Net，LBCNet)，在轻量化模型的辐射源识别性能方面有了大幅度提升。GAO 等[19]仅在仿真数据集上进行测试，并未应用在实际情况中，真实场景下的辐射源信号往往受信号衰落、阴影效应等影响，表现出信号信噪比较低等复杂现象。但该文献也为辐射源识别轻量化提供了新思路，即采用轻量化卷积实现轻量化目标，再通过添加轻量化注意力模块弥补轻量化造成的性能下降。

基于以上研究，针对极端情况下边缘端设备算力受限时，现有模型难以满足实时性要求这一问题，本文提

出了基于一维深度可分离卷积和一维卷积块注意力模块的网络(ODCNet)架构。具体地，为减少模型的参数量和计算复杂度，基于一维深度可分离卷积，结合逐深度卷积和逐点卷积，构造轻量化模型框架；同时，为提升网络提取辐射源信号时序性特征的能力，基于一维卷积块注意力模块辅助提取信号时序特征。在 ADS–B 和 Tetra 对讲机数据集上进行实验，实验结果表明，ODCNet 更加适配信号的一维特性，在减少模型参数量与计算复杂度的同时，具备良好的识别精确度、实时性与噪声鲁棒性。

1　辐射源识别相关知识

1.1 辐射源识别基础内容

辐射源个体识别技术的核心问题在于能否认知到设备指纹信息的差异性。常见的辐射源个体信号包括 ADS–B 信号、对讲机信号等。ADS–B 通过网状、多点对多点的方式实现双向通信。ADS–B 系统分为 OUT(发送)和 IN(接收)2 个子系统，均采用数据链通信技术。其最大下行数据长度达到 112 bit，最大比特率达到 1 Mbit/s。典型的报文格式如图 1 所示，其中：DF 表示下行数据链格式；CA 表示应答器能力；ICAO 为飞机地址位；ME 字段包含具体消息，如，时间指示、CPR 编码格式、维度、经度等信息；PI 为奇偶校验/询问器标识位；括号中的数字表示该字段的位数。

Fig.1 ADS–B message format
图 1　ADS–B 报文格式

完整的 ADS–B 数据长度为 120 μs，包括前导脉冲 8 μs 和数据脉冲 112 μs。其中，前导脉冲主要提供信息到达时间和脉冲参考电平等参数信息。

但在无线通信中，信号并不以报文格式发送，而是通过编码、成型滤波、调制等一系列操作将辐射源信号变为离散时间信号进行传输。接收方接收到的信号通常为 I/Q 两路的离散时间信号，一般将其保存为 mat 或 wav 格式，以便后续数据处理。

1.2 常见辐射源识别架构

通常将辐射源识别任务视作识别类型的问题，采用一般的识别模型架构，如图 2 所示。首先通过预处理读取接收到的信号，将信号转变为计算机易于处理/识别的格式，然后使用神经网络进行特征提取，再通过分类器进行识别，并使用交叉熵损失函数为引导，不断优化网络识别结果。

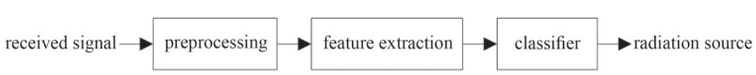

Fig.2 Structure of emitter identification
图 2　辐射源识别一般架构

这种架构的核心在于特征提取部分，深度神经网络以其强大的特征提取能力成为特征提取部分的核心技术。能够充分提取信号时序特征的 RNN、Transformer 等时序性神经网络往往伴随着长程依赖、复杂度高等问题，而卷积神经网络则无法充分利用辐射源信号的时序特性。为改善这一问题，本文在卷积神经网络的基础上引入了轻量化模块——卷积块注意力模块，在几乎不引入额外开销的前提下进一步改善了网络性能。

2　轻量化辐射源识别方法

为解决极端情况下边缘端算力受限，现有模型难以满足实时性要求这一问题，本文提出基于轻量化网络的辐射源识别模型 ODCNet。该模型的基础模块由两部分组成：一维深度可分离卷积(One–Dimensional Depthwise Separable Convolution，1D–DSC)和一维卷积块注意力模块(One–Dimensional Convolutional Block Attention Module，1D–CBAM)。其中，一维深度可分离卷积以其参数量与计算复杂度低成为轻量化网络的主干部分，负责轻量化与特征提取主体部分。一维卷积块注意力模块凭借其几乎不引进额外开销的轻量性质与即插即用的便利性承担起辅助特征提取的功能。

深度可分离卷积与卷积块注意力模块是针对图像识别任务提出的，采用二维卷积，在一维的辐射源识别任务中性能有限且造成不必要的计算成本。为适应信号的一维特性，将二维卷积改进成一维卷积，进一步减少模型参数量与计算复杂度。

此外，不同于以往的模型通常使用批归一化(Batch Norm，BN)，本文使用层归一化(Layer Norm，LN)进行特征归一化，保留了样本间不同特征的相对大小关系，有利于模型学习到最具区分性的辐射源信号指纹特征。识别流程图如图3所示，其中功率谱密度(Power Spectral Density，PSD)模块计算信号功率谱密度，num为辐射源种类数，type为最终输出的辐射源种类。

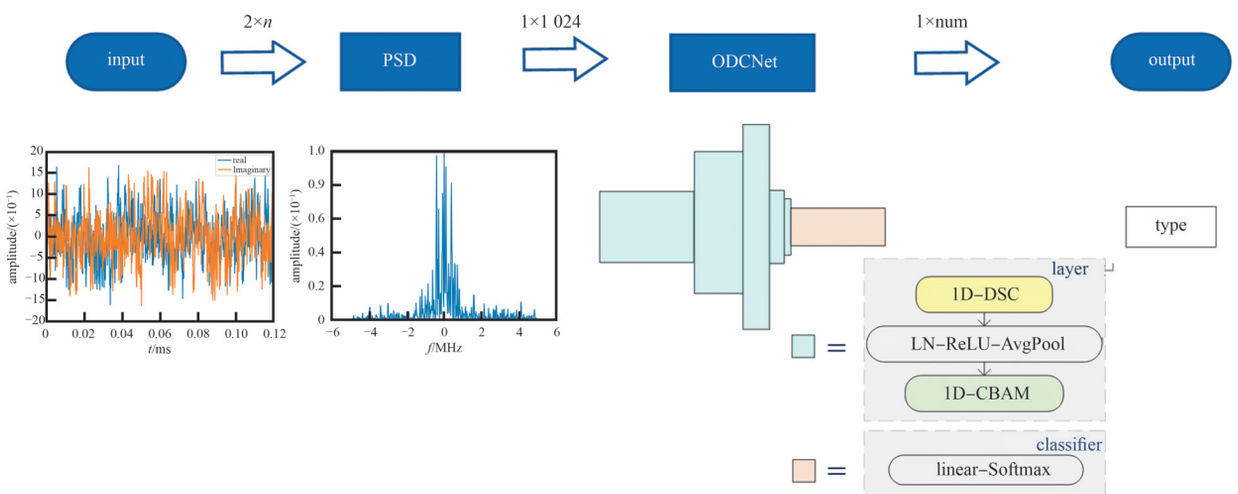

Fig.3 Flowchart for identification of radiation sources

图3 辐射源识别流程图

2.1 深度可分离卷积

深度可分离卷积[14]是在标准卷积的基础上改造而来。深度可分离卷积在图像领域应用广泛，因此多采用二维卷积。为适应信号的一维特性，本文在二维深度可分离卷积的基础上进行改进，使用一维卷积替代二维卷积。以3通道输入为例，一维标准卷积的计算过程如图4所示，改进后的一维深度可分离卷积的计算过程如图5所示。

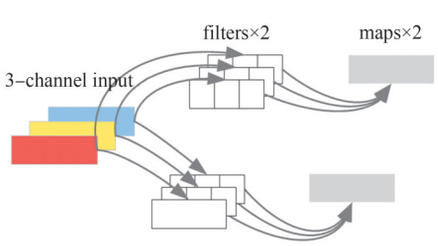

Fig.4 Standard convolution

图4 标准卷积

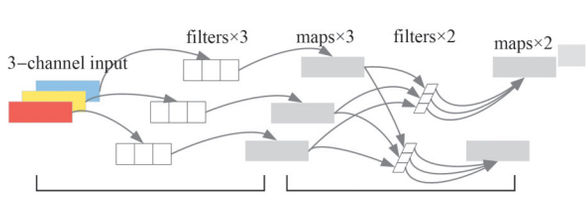

Fig.5 Depthwise separable convolution

图5 深度可分离卷积

标准一维卷积过程中涉及到的参数量为：$M_{\text{out\_channels}} \times k \times M_{\text{in\_channels}}$，其中，$M_{\text{out_channels}}$为输出通道数，$k$为一维卷积核大小，$M_{\text{in_channels}}$为输入通道数目。

深度可分离卷积的计算分为两步。逐深度卷积(Depthwise Convolution，DC)的一个卷积核负责一个通道，其参数量为$k \times M_{\text{in_channels}}$，$k$为一维卷积核大小。逐点卷积(Pointwise Convolution，PC)与标准卷积一致，但其卷积核大小为1，因此逐点卷积过程中涉及到的参数量为$1 \times M_{\text{out_channels}}$。因此深度可分离卷积计算过程中涉及到的参数量为$k \times M_{\text{in_channels}} + 1 \times M_{\text{out_channels}}$。

二者参数量之比为：

$$\frac{k \times M_{\text{in\_channels}} + 1 \times M_{\text{out\_channels}}}{M_{\text{out\_channels}} \times k \times M_{\text{in\_channels}}} = \frac{1}{M_{\text{out\_channels}}} + \frac{1}{k \times M_{\text{in\_channels}}}$$

由上述对比分析可知，深度可分离卷积通过拆分空间维度与深度/通道维度，减少了标准卷积的参数量；且卷积核越大，参数量越少。

2.2 卷积块注意力模块

卷积块注意力模块(CBAM)是一种结合了空间注意力机制和通道注意力机制的模块。给定一个中间特征图，CBAM 模块会沿着 2 个独立的维度(通道和空间)依次推断注意力图，然后将注意力图与输入特征图相乘以进行自适应特征优化[20]。改进后的一维卷积块注意力模块原理图如图 6 所示。

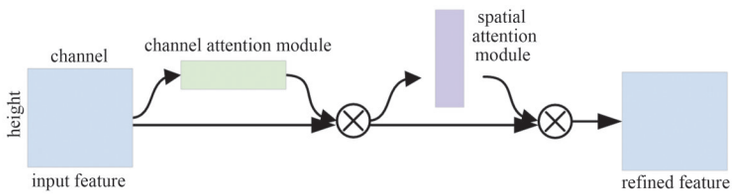

Fig.6 Convolutional block attention module
图 6　卷积注意力机制模块

改进后的一维通道注意力模块结构如图 7 所示。对输入特征图 $\boldsymbol{F}\in\mathbb{R}^{C\times H}$ 的高度维度进行全局最大池化和全局平均池化，并将得到的 2 个子图分别经过多层感知机，然后将二者逐元素相加并经过 Sigmoid 函数激活得到其通道注意力权值 $\boldsymbol{M}_{\mathrm{c}}\in\mathbb{R}^{C\times 1}$。通道注意力模块的计算流程为：

$$\boldsymbol{M}_{\mathrm{c}}=\sigma\left\{\mathrm{MLP}\left[\mathrm{AvgPool}(\boldsymbol{F})\right]+\mathrm{MLP}\left[\mathrm{MaxPool}(\boldsymbol{F})\right]\right\}=\sigma\left\{\boldsymbol{W}_1\left[\boldsymbol{W}_0(\boldsymbol{F}_{\mathrm{avg}}^{\mathrm{c}})\right]+\boldsymbol{W}_1\left[\boldsymbol{W}_0(\boldsymbol{F}_{\mathrm{max}}^{\mathrm{c}})\right]\right\}\tag{1}$$

式中：$\boldsymbol{F}_{\mathrm{avg}}^{\mathrm{c}}$ 为输入特征图 $\boldsymbol{F}$ 经过通道注意力模块的 AvgPool 后得到的向量；$\boldsymbol{F}_{\mathrm{max}}^{\mathrm{c}}$ 为输入特征图 $\boldsymbol{F}$ 经过通道注意力模块 MaxPool 后得到的向量；$\boldsymbol{W}_0$、$\boldsymbol{W}_1$ 为多层感知机的权重。

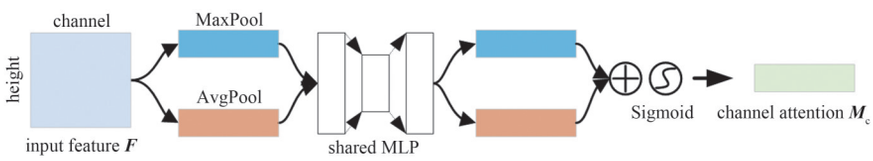

Fig.7 Channel attention module
图 7　通道注意力模块

改进后的一维空间注意力模块结构如图 8 所示。将通道注意力模块的输出 $\boldsymbol{M}_{\mathrm{c}}$ 与原始特征图 $\boldsymbol{F}$ 相乘后得到的 $\boldsymbol{F}'$ 作为空间注意力模块的输入。该模块首先经过基于通道的全局最大池化和全局平均池化，并将得到的 2 个子图连接起来；然后通过卷积层使特征图恢复至原始子图大小，其中卷积层的卷积核大小为 7，并通过补零的方式保证卷积前后维度一致；最后经过 Sigmoid 函数激活得到空间注意力权值 $\boldsymbol{M}_{\mathrm{s}}\in\mathbb{R}^{C\times 1}$。其计算流程为：

$$\boldsymbol{M}_{\mathrm{s}}=\sigma\left\{f^{7}\left(\left[\mathrm{AvgPool}(\boldsymbol{F}');\mathrm{MaxPool}(\boldsymbol{F}')\right]\right)\right\}=\sigma\left\{f^{7}\left(\left[\boldsymbol{F}_{\mathrm{avg}}^{\mathrm{s}};\boldsymbol{F}_{\mathrm{max}}^{\mathrm{s}}\right]\right)\right\}\tag{2}$$

式中：$\boldsymbol{F}'$ 为通道注意力权值 $\boldsymbol{M}_{\mathrm{c}}$ 与输入特征图 $\boldsymbol{F}$ 相乘得到的特征图；$\boldsymbol{F}_{\mathrm{avg}}^{\mathrm{s}}$ 为特征图 $\boldsymbol{F}'$ 经过空间注意力模块的 AvgPool 操作后得到的向量；$\boldsymbol{F}_{\mathrm{max}}^{\mathrm{s}}$ 为特征图 $\boldsymbol{F}'$ 经过空间注意力模块 MaxPool 操作后得到的向量；f^{7} 为卷积核大小为 7 的卷积操作。

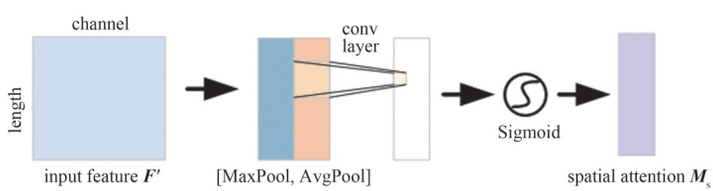

Fig.8 Spatial attention module
图 8　空间注意力模块

3　实验

3.1 数据预处理

ADS–B 数据集包含 10 架飞机，其航班号分别为：780B88、780C2D、780D5E、780D6C、7809B8、7815A2、7817AE、78027B、78112C、780277。每架飞机包含 3 000~5 000 条数据，采样率为 10 MHz。

Tetra 对讲机数据集包含 3 台对讲机，分别标记为 1、2、3 类，采样率为 2 048 kHz，并将 Tetra 辐射源信号以

8 192 个采样点为一条子信号进行切分，则每台对讲机包含 7 000~8 000 条数据。

信号的频域包含其频率分量等具有显著区分性的特征，因此绘制输入数据的功率谱密度作为模型输入。Welch 周期图法[21]是一种常用的功率谱密度估计算法，其计算过程简单快捷，并且能够克服周期性干扰的影响。基于 Welch 法的功率谱密度估计步骤如下：a) 将信号按长度为 N 进行切分；b) 将每一段信号通过窗函数，常用的窗函数有汉宁窗、汉明窗、Kaisr 窗等；c) 对每一段信号进行快速傅里叶变换(Fast Fourier Transform，FFT)，并计算 FFT 的幅度平方，得到每个段的功率谱密度估计值；d) 对每段信号的功率谱密度估计结果求和平均，得到信号平均功率谱密度。

3.2 参数设置

网络模型基于 Pytorch 框架，硬件配置为 NVIDIA GeForce RTX 3050，运行内存 16 GB；绘制输入 I/Q 数据的功率谱密度，将输入数据转换为 1×1 024 格式；模型训练过程中采用 Adam 优化器进行梯度下降，每次迭代样本数为 1 024，训练次数为 400 轮次；初始学习率为 0.001。模型各层参数设置如表 1 所示，其中 s 表示步长。

表 1 模型各层参数设置

Table1 Parameter settings for each layer of the model

layer		parameter
DSC	DC	$M_{in\_channels}$=1, $M_{out\_channels}$=1, k=4, s=2
	PC	$M_{in\_channels}$=1,$M_{out\_channels}$=64,k=1,s=2
		LN–ReLU–AvgPool(k=2)–CBAM(64)
DSC	DC	$M_{in\_channels}$=64, $M_{out\_channels}$=64, k=2, s=1
	PC	$M_{in\_channels}$=64, $M_{out\_channels}$=128, k=1, s=1
		LN–ReLU–AvgPool(k=2)–CBAM(128)
DSC	DC	$M_{in\_channels}$=128, $M_{out\_channels}$=128, k=2, s=1
	PC	$M_{in\_channels}$=128, $M_{out\_channels}$=256, k=1, s=1
		LN–ReLU–AvgPool(k=2)–CBAM(256)
DSC	DC	$M_{in\_channels}$=256, $M_{out\_channels}$=256, k=2, s=1
	PC	$M_{in\_channels}$=256, $M_{out\_channels}$=64, k=1, s=1
		LN–ReLU–AvgPool(k=2)–CBAM(64)
DSC	DC	$M_{in\_channels}$=64, $M_{out\_channels}$=64,k=2, s=1
	PC	$M_{in\_channels}$=64, $M_{out\_channels}$=16, k=1, s=1
		LN–ReLU–AvgPool(k=2)–CBAM(16)
linear		$M_{in\_features}$=16×6, $M_{out\_features}$=num
		Softmax

对比方案包括经典模型 ResNet18 和一些轻量化模型，如，基于二维深度可分离卷积的 MobileNet V3 small、基于分组点卷积和通道洗牌的 ShuffleNet V2、基于 Ghost 模块的 GhostNet 与基于部分卷积的 FasterNet[22]。

3.3 对比实验

绘制辐射源信号功率谱密度输入至 ODCNet 中，利用 ODCNet 充分提取信号特征，并做出决策，得到模型在 ADS–B 测试集和 Tetra 测试集上的识别混淆矩阵，如图 9 所示。由 ADS–B 测试集混淆矩阵可以看出，ODCNet 对于 ADS–B 数据集具备较强的辐射源识别能力，其总体识别准确率达到 97.67%。

考虑到 ADS–B 数据遵循相同的报文格式，信号规则性较强，相对而言易于区分。使用 Tetra 数据集进一步测试模型的识别能力，结果如图 9(b)所示。可以看出，对讲机 1 和对讲机 2 中存在部分错判情况。但对于对讲机 1，识别准确率达到了 88%，结果较理想。

为进一步说明模型的轻量化效果，将 ODCNet 与其他经典模型在识别准确率(Accuracy)、模型参数量(Params)、模型计算复杂度(每秒浮点运算次数(Floating Point Operations Per Second，FLOPs))和模型在测试集上的推理时间(Time)4 个方面进行比较，输入均为信号的功率谱密度，结果如表 2 所示。

由表 2 可得，在 ADS–B 数据集上，ODCNet 与其他模型相比，识别准确率相差 2 个百分点，而参数量与计算复杂度大大降低，ResNet18 性能最优，符合预期结果(ResNet18 并非轻量化模型)。而在 Tetra 数据集上，GhostNet、FasterNet 等模型虽然取得了较好的识别效果，但在测试集上的推理时间远多于 ODCNet。此外，ODCNet 在识别准确率与 MobileNet V3 small 相当的情况下，计算复杂度仅为 MobileNet V3 small 的 1/7，且在测试集上的推理速度最快，仅为 MobileNet V3 small 的 1/2。这表明 ODCNet 模型具备相当强的瞬时计算能力，在信息安全等及时性要求更高的攻防领域具备一定优势。

3.4 噪声鲁棒性实验

进一步测试 ODCNet 对噪声的鲁棒性。以 ADS–B 数据集为例，在数据集中加入高斯白噪声，模拟恶劣信道

环境下辐射源信号传输，遵循文献[23]中实验设置，使信号信噪比(Signal-to-Noise Ratio，SNR)处于-18~10 dB范围内(每2 dB)。ODCNet的识别准确率随信噪比变化情况如图10所示。由图10可知，模型在较低信噪比下仍具有良好的识别能力。在十分类任务中，即使在信噪比为-10 dB时，对其中6个辐射源识别准确率仍超过80%。信噪比大于-4 dB时，对所有辐射源识别准确率均大于80%。

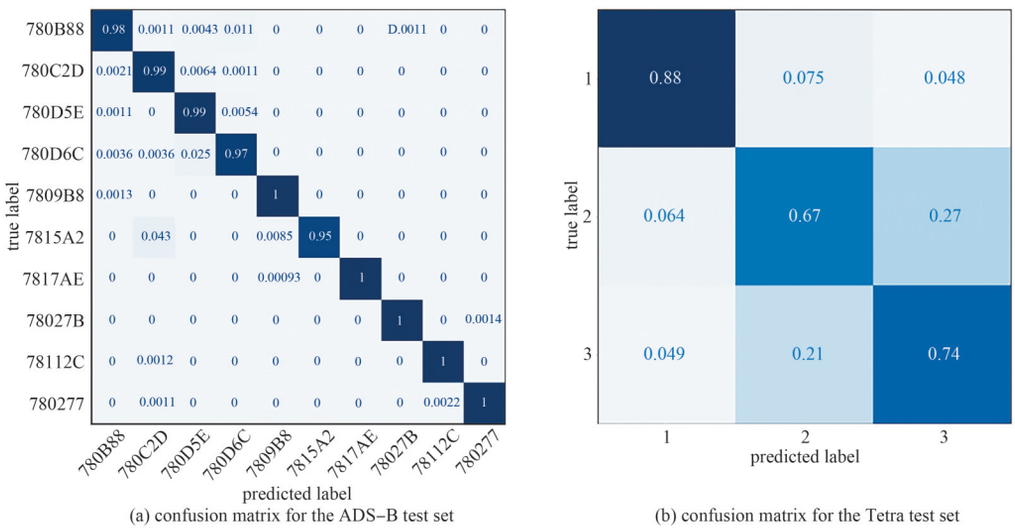

(a) confusion matrix for the ADS-B test set　　(b) confusion matrix for the Tetra test set

Fig.9 Confusion matrix

图9 混淆矩阵

表2 各模型评价指标分析

Table2 Analysis of evaluation indicators for each model

dataset	model	accuracy/%	Params/K	FLOPs/M	Time/s
ADS-B	ResNet18	**99.84**	11 181.642	513.725 952	1.716 1
	MobileNet V3 small	99.73	1 528.106	21.737 272	0.804 8
	GhostNet	99.75	3 914.318	53.267 296	9.343 6
	ShuffleNet V2	99.73	1 263.854	54.905 856	1.051 1
	FasterNet	99.63	12 937.098	607.802 624	6.401 2
	ODCNet	97.67	**172.17**	**3.802 291**	**0.362 4**
Tetra	ResNet18	79.58	11 178.051	513.722 368	0.545 1
	MobileNet V3 small	75.55	1 520.931	21.730 104	0.414 5
	GhostNet	**85.20**	3 905.351	53.258 336	6.684 0
	ShuffleNet V2	80.35	1 256.679	54.898 688	0.545 1
	FasterNet	83.72	12 928.131	607.793 664	5.596 4
	ODCNet	75.41	**171.491**	**3.081 598**	**0.205 0**

为进一步展示模型的识别能力，制作模型在各信噪比处的平均识别情况如表3所示。由表3可知，模型在测试集上的平均识别准确率达到83.12%。在信噪比为-10 dB下，其识别准确率为80.34%，精确率为95.25%。在R_{SN}≥-10 dB时，精确率始终大于95%。较高的精确率表明模型在低信噪比下，仍能够有效减少虚警。模型在信噪比较低时，仍能够具有较高的识别准确率与高精确率，表明模型的噪声鲁棒性较强。

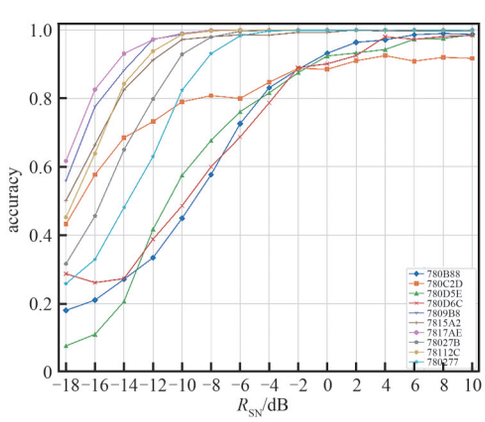

Fig.10 Variation of recognition accuracy with SNR

图10 识别准确率随信噪比变化情况

4　结论

本文结合信号的一维特性，对深度可分离卷积做出改进，并结合卷积块注意力模块提出一种新的轻量化模型ODCNet，在减少参数量与运算复杂度的同时达到较好的识别精确度并实现了模型推理加速。通过与经典模型对比，充分说明了在边缘端算力受限的极端情况下ODCNet的实时性优势。最后，通过噪声鲁棒性实验说明了模型的抗噪声性能较优，有利于识别在恶劣信道条件下传输的辐射源信号。

表3 模型在各信噪比处的平均识别情况

Table3 Average recognition performance of the model at various SNRs

R_{SN}/dB	accuracy/%	precision/%	recall/%	F1 score/%
−18	37.16	72.95	37.16	47.57
−16	49.45	79.65	49.45	58.58
−14	60.85	86.66	60.85	68.56
−12	71.48	92.45	71.48	78.35
−10	80.34	95.25	80.34	85.78
−8	85.72	96.89	85.72	90.11
−6	89.58	97.81	89.58	93.12
−4	92.63	97.97	92.63	95.04
−2	95.34	99.08	95.34	97.09
0	96.38	99.12	96.38	97.65
2	97.30	99.26	97.30	98.22
4	98.15	99.42	98.15	98.74
6	98.40	99.55	98.40	98.93
8	98.56	99.63	98.56	99.06
10	98.76	99.79	98.76	99.24

参考文献：

[1] LIN Yun,ZHA Haoran,TU Ya,et al. GLR-SEI:green and low resource specific emitter identification based on complex networks and fisher pruning[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2024, 8(5): 3239-3250. DOI: 10.1109/TETCI.2023.3303092.

[2] 陈韬伟,辛明. 基于小波变换的雷达辐射源信号特征提取[J]. 太赫兹科学与电子信息学报, 2010,8(4):436-440. (CHEN Taowei,XIN Ming. Feature extraction based on wavelet transform for radar emitter signals[J]. Journal of Terahertz Science and Electronic Information Technology, 2010,8(4):436-440.) DOI:10.3969/j.issn.1672-2892.2010.04.014.

[3] 李靖超,应雨龙. 基于功率谱密度的通信辐射源个体识别方法[J]. 太赫兹科学与电子信息学报, 2021,19(4):596-602. (LI Jingchao,YING Yulong. Individual identification method of communication radiation source based on power spectral density[J]. Journal of Terahertz Science and Electronic Information Technology, 2021,19(4):596-602.) DOI:10.11805/TKYDA2021140.

[4] D'AGOSTINO S. Specific emitter identification based on amplitude features[C]// 2015 IEEE International Conference on Signal and Image Processing Applications(ICSIPA). Kuala Lumpur,Malaysia:IEEE, 2015:350-354. DOI:10.1109/ICSIPA.2015.7412216.

[5] TOONSTRA J,KINSNER W. A radio transmitter fingerprinting system ODO-1[C]// Proceedings of 1996 Canadian Conference on Electrical and Computer Engineering. Calgary,AB,Canada:IEEE, 1996:60-63. DOI:10.1109/CCECE.1996.548038.

[6] SHI Y,JENSEN M A. Improved radiometric identification of wireless devices using MIMO transmission[J]. IEEE Transactions on Information Forensics and Security, 2011,6(4):1346-1354. DOI:10.1109/TIFS.2011.2162949.

[7] YUAN Yingjun,HUANG Zhitao,WU Hao,et al. Specific emitter identification based on Hilbert-Huang transform-based time-frequency-energy distribution features[J]. IET Communications, 2014,8(13):2404-2412. DOI:10.1049/iet-com.2013.0865.

[8] 刘文斌,范平志,李雨锴,等. 辐射源个体识别的一种可解释性测试架构[J]. 太赫兹科学与电子信息学报, 2023,21(6):734-744. (LIU Wenbin, FAN Pingzhi, LI Yukai, et al. An interpretable testing architecture for specific emitter identification[J]. Journal of Terahertz Science and Electronic Information Technology, 2023,21(6):734-744.) DOI:10.11805/TKYDA2022243.

[9] XIAO Yao, WEI Xizhang. Specific emitter identification of radar based on one dimensional convolution neural network[J]. Journal of Physics:Conference Series, 2020,1550(3):032114. DOI:10.1088/1742-6596/1550/3/032114.

[10] WU Bin, YUAN Shibo, LI Peng, et al. Radar emitter signal recognition based on one-dimensional convolutional neural network with attention mechanism[J]. Sensors, 2020,20(21):6350. DOI:10.3390/s20216350.

[11] ZHU Zhigang, JI Hongbing, ZHANG Wenbo, et al. Complex convolutional neural network for signal representation and its application to radar emitter recognition[J]. IEEE Communications Letters, 2023, 27(3): 856-860. DOI: 10.1109/LCOMM. 2023. 3234464.

[12] LI Xueqiong, LIU Zhangmeng, HUANG Zhitao, et al. Radar emitter classification with attention-based multi-RNNs[J]. IEEE Communications Letters, 2020,24(9):2000-2004. DOI:10.1109/LCOMM.2020.2995842.

[13] QU Lingzhi, YANG Junan, HUANG Keju, et al. Specific emitter identification based on one-dimensional complex-valued residual networks with an attention mechanism[J]. Bulletin of the Polish Academy of Sciences:Technical Sciences, 2021,69(5): 138814. DOI:10.24425/bpasts.2021.138814.

[14] HOWARD A G,ZHU M L,CHEN B,et al. Mobilenets:efficient convolutional neural networks for mobile vision applications[J/OL]. arXiv:1704.04861, 2017. DOI:10.48550/arXiv.1704.04861.

[15] ZHANG Xiangyu,ZHOU Xinyu,LIN Mengxiao,et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City,UT,USA:IEEE, 2018: 6848-6856. DOI:10.1109/CVPR.2018.00716.

[16] HAN Kai,WANG Yunhe,TIAN Qi,et al. GhostNet:more features from cheap operations[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Seattle, WA, USA: IEEE, 2020: 1577-1586. DOI: 10.1109/CVPR42600.2020.00165.

[17] DENG Pengfei,HONG Shaohua,QI Jie,et al. A lightweight transformer-based approach of specific emitter identification for the automatic identification system[J]. IEEE Transactions on Information Forensics and Security, 2023(18): 2303-2317. DOI: 10.1109/TIFS.2023.3266627.

[18] 王艺卉,闫文君,徐从安,等. 面向ADS-B信号辐射源个体识别的轻量化模型设计[J]. 太赫兹科学与电子信息学报, 2023,21(9):1100-1108. (WANG Yihui,YAN Wenjun,XU Congan,et al. Design of lightweight model for specific emitter identification of ADS-B signal[J]. Journal of Terahertz Science and Electronic Information Technology, 2023,21(9):1100-1108.) DOI:10.11805/TKYDA2023077.

[19] GAO Jingpeng,SONG Xia,GAO Lu. Individual identification algorithm of known emitters based on lightweight binary channels neural network[C]// The 12th International Conference on Information Technology in Medicine and Education. Xiamen,China: IEEE, 2022:223-227. DOI:10.1109/ITME56794.2022.00057.

[20] WOO S,PARK J,LEE J Y,et al. CBAM:convolutional block attention module[C]// Computer Vision-ECCV 2018. Munich, Germany:Springer, 2018:3-19. DOI:10.1007/978-3-030-01234-2_1.

[21] WELCH P. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms[J]. IEEE Transactions on Audio and Electroacoustics, 1967,15(2):70-73. DOI: 10.1109/TAU.1967.1161901.

[22] CHEN J R,KAO S H,HE H,et al. Run,don't walk:chasing higher FLOPS for faster neural networks[C]// 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR). Vancouver, BC, Canada: IEEE, 2023: 12021-12031. DOI: 10.1109/CVPR52729.2023.01157.

[23] SI Weijian,LUO Jiaji,DENG Zhian. Radar signal recognition and localization based on multiscale lightweight attention model[J]. Journal of Sensors, 2022(1):9970879. DOI:10.1155/2022/9970879.

作者简介：

孙文鑫(1999-)，女，在读硕士研究生，主要研究方向为智能信号处理.email:swx@my.swjtu.edu.cn.

孟　华(1982-)，男，博士，副教授，主要研究方向为拓扑学、机器学习.

杨佳煌(1999-)，男，在读博士研究生，主要研究方向为深度学习.

周礼亮(1982-)，男，在读博士研究生，主要研究方向为智能信息处理系统.